

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I
INFORMACIJSKI TEHNOLOGIJA OSIJEK**

Sveučilišni studij

**OPTIMALNA PONUDA SUSTAVA
VJETROELEKTRANE I ELEKTRANE NA BIOMASU
NA TRŽIŠTU ELEKTRIČNE ENERGIJE**

Diplomski rad

Marin Medved

Osijek, 2018.

SADRŽAJ

1. UVOD	1
1.1. Zadatak diplomskog rada.....	1
2. TRŽIŠTE ELEKTRIČNE ENERGIJE.....	2
2.1. Struktura tržišta.....	2
2.2. Vremenska dimenzija tržišta	2
2.3. Penalizacija zbog uzrokovanja neravnoteže	3
3. VJETROELEKTRANE NA TRŽIŠTU ELEKTRIČNE ENERGIJE	5
3.1. Trenutno stanje vjetroelektrana u Europi i svijetu.....	5
3.2. Konkurentnost vjetroelektrana na tržištu el. energije.....	7
4. ELEKTRANE NA BIOMASU NA TRŽIŠTU ELEKTRIČNE ENERGIJE.....	11
5. MATEMATIČKI MODEL SUSTAVA.....	13
5.1. Realizacija modela.....	13
5.2. Ograničenja modela	14
5.2.1. Troškovi pokretanja	14
5.2.2. Ograničenje ravnoteže pogonskog goriva.....	16
5.2.3. Dodatna ograničenja	17
5.3. Model minimalizacije gubitaka penala zbog uzrokovane neravnoteže	18
6. PROVOĐENJE MATEMATIČKOG MODELA	20
6.1. Izračun i unos početnih parametara	20
6.2. Simulacija za slučaj bez premija	22
6.3. Simulacija za slučaj sa premijom	28
6.4. Simulacija za slučaj sa premijom i bilateralnim ugovorom od 20 MWh	32
7. ZAKLJUČAK	35
Literatura	36
Životopis.....	37
Sažetak	38
Abstract	38
Prilog	39

1. UVOD

U radu je teorijski obrađeno tržište električne energije, posebice penalizacija tržišnih sudionika zbog uzrokovanja neravnoteže. Treće i četvrto poglavlje opisuju trenutno stanje obnovljivih izvora električne energije s posebnim osvrtom na vjetroelektrane i elektrane na biomasu te pregled njihove trenutne zastupljenosti u proizvodnom sustavu Europe i svijeta.

Peto poglavlje sadrži uvid u dva matematička modela sa njihovim funkcijama cilja i ograničenjima koji su korišteni za dobivanje rješenja problematike kojom se rad bavi. Za potrebe provođenja modela korišten je MATLAB.

Naposljetku, u šestom poglavlju, analizirani su i grafički prikazani rezultati tri slučaja promatranog proizvodnog sustava dobiveni matematičkim modelom. Prokomentiran je svaki od tri simulirana scenarija te su izvučeni zaključci o isplativosti obnovljivih izvora.

1.1. Zadatak diplomskog rada

U diplomskom radu potrebno je teorijski obraditi mogućnost davanja ponuda na tržištu električne energije za sustav vjetroelektrane i elektrane na biomase. Nadalje, potrebno je izraditi računalni optimizacijski model vjetroelektrane i elektrane na biomasu s ciljem određivanja zajedničke optimalne ponude obzirom na očekivane vrijednosti cijena na tržištu električne energije.

2. TRŽIŠTE ELEKTRIČNE ENERGIJE

U teoriji, tržište se definira kao stalan i organiziran oblik dovođenja u kontakt ponude i potražnje roba i usluga te je ujedno i mehanizam kojim se reguliraju odnosi prodavača i kupaca u uvjetima u kojima sudionici ostvaruju svoje ciljeve i interese. Osnovu tržišta čine ponuda i potražnja. Skupina koja određuje potražnju za nekim proizvodom su kupci, dok su proizvođači skupina koja određuje ponudu. [1]

Specifičnost tržišta električne energije je u tome što se dobro kojim se trguje, odnosno električna energija, ne može skladištiti. Zbog toga u svakom trenutku proizvodnja električne energije mora biti jednaka potrošnji električne energije.

2.1. Struktura tržišta

Potrebno je naglasiti da je trgovanje električnom energijom drugačije od trgovanja na klasičnim tržištima drugih dobara. Razlog tomu je da se električna energija zbog svojih specifičnih karakteristika razlikuje od ostalih proizvoda kojima se trguje. Prva, pomalo očita odlika je da električna energija nije opipljiva. Naime, električna energija zahtjeva neprekidan tok, odnosno da se električna energija proizvodi i troši u kontinuitetu. Uz to, uzevši dodatno u obzir i činjenicu da je električna energija proizvod koji se ne može skladištiti, mora postojati istodobna proizvodnja i potrošnja jer za sustav mora vrijediti da je u svakom trenutku proizvodnja električne energije jednaka potrošnji uvećanoj za gubitke u prijenosnoj i distribucijskoj mreži. U suprotnom, dolazi do neravnoteže koja uzrokuje raspad sustava, a to nameće dodatne troškove potrošačima i proizvođačima. [2]

2.2. Vremenska dimenzija tržišta

Ranije je spomenuto kako je električna energija specifičan proizvod pa kao takva zahtjeva specifično tržište. Kao i svako drugo tržište, tržište električne energije zahtjeva ravnotežu proizvodnje i potrošnje. Međutim, situaciju otežava činjenica da se opterećenje sustava konstantno mijenja pa je tu ravnotežu teže postići i održavati u svakom trenutku dana. Drugim riječima, zakon ponude i potražnje, kojim se inače tržište dovodi u ravnotežu, nije dovoljno učinkovit u ovakvim situacijama, odnosno ne djeluje dovoljno brzo. Posljedica toga je da cijena energije mora biti utvrđena prije ili poslije realnog vremena. Zbog potrebe za konstantnom ravnotežom idealan slučaj, iako nerealan i nepraktičan, bio bi organizacija posebnih tržišta za svaku sekundu dana. Iako tako nešto ne postoji, koncept različitih tržišta se

primjenjuje. Za svaki sat u danu postoji odvojeno tržište svako sa svojim krivuljama potrošnje i proizvodnje i svojom cijenom. [2]

Kada se govori o vremenskoj dimenziji tržišta, bitno je razlikovati trenutak kada je trgovina zaključena te trenutak kada je došlo do isporuke proizvoda. Prema [2], uzimajući u obzir vrijeme potrebno za dostavu fizičke robe od trenutka zaključivanja trgovine, tržišta električne energije dijele se na promptna (tekuća, spot) tržišta i buduća tržišta.

U teoriji, spot ili promptno tržište, kao što samo ime govori, je tržište na kojemu se kupljena roba dostavlja odmah nakon zaključivanja trgovine. Budući da je gotovo nemoguće izvesti tržište na kojemu bi se električna energija dostavljala doslovno odmah nakon trgovine, spot tržišta obuhvaćaju unutardnevno tržište, kao i tržište za dan unaprijed gdje se električna energija dostavlja sljedeći sat, odnosno sljedeći dan. Ono što je negativno na ovakvim tržištima je stalna promjenjivost i nepredvidivost cijene. [1]

Buduće tržište ispravlja tu manu jer ono nudi stabilniju i u neku ruku predvidivu cijenu. Takvo tržište podrazumijeva bilo koje tržište kojemu je razdoblje između trgovine i fizičke dostave energije duže od jednog dana. Na ovakvom tržištu, sudionici međusobno ugovaraju dugoročne ugovore koji mogu biti tjedni, mjesečni ili godišnji te kojima je određena količina, lokacija i cijena električne energije. [1]

2.3. Penalizacija zbog uzrokovanja neravnoteže

Već je ranije spomenuto kako je važna odlika tržišta električnom energijom potreba za stalnom ravnotežom između ponude i potražnje. Zbog toga se velika važnost pridaje prognoziranju potražnje i planiranju ponude, odnosno proizvodnje električne energije. Odstupanje od prognoziranih količina uzrokuje neravnotežu sustava te se penalizira.

Do neravnoteže dolazi odstupanjem proizvodnje ili potrošnje od prethodno ugovorenih količina energije. Penalizacija se provodi na dva načina, sustavom jedinstvene cijene i sustavom dvojnih cijena. [2]

Kada proizvođač ne proizvede ugovorenu količinu električne energije, pri korištenju sustava jedinstvene cijene, on je dužan platiti nabavnu cijenu energije uravnoteženja. [2]

U sustavu dvojnih cijena razlikuju se dva slučaja, kada je došlo do manjka proizvodnje u odnosu na potrošnju i slučaj manjka potrošnje na proizvodnju. Operator sustava određuje

cijene penala za svaki slučaj. Zbog toga na tržištu uravnoteženja postoje dvije vrste ponuda, ponude za regulaciju na gore (engl. *up regulation*) kada je potrebno povećanje proizvodnje i smanjenje potrošnje i ponude za regulaciju na dolje (engl. *down regulation*) kod kojih je potrebno smanjenje proizvodnje i povećanje potrošnje. [2]

Operator prijenosnog sustava je jedini kupac na tržištu uravnoteženja i on kupuje aktivirane ponude, a sve usluge uravnoteženja operator prijenosnog sustava naplaćuje tržišnom sudioniku koji je uzrokovao neravnotežu. Kod nastanka neravnoteže, najprije je potrebno klasificirati radi li se o satu regulacije na dolje ili satu regulacije na gore kako bi se odredila cijena po kojoj će se cijeni naplaćivati uravnoteženje. Cijena regulacije na gore (engl. *up-regulating price*) jednaka je cijeni najskuplje ponude za regulacije na gore u promatranom satu koja mora biti jednaka ili veća od spot cijene (Spot cijena je cijena na tržištu dan unaprijed). Cijena regulacije na dolje (engl. *down-regulating price*) je jednaka najjeftinijoj ponudi za regulaciju na dolje za promatrani sat i koja je manja ili jednaka od spot cijene za isti promatrani sat. [2]

Tablica 2.1. Sustav dvojnih cijena za proizvođače za uzrokovanu neravnotežu [2]


	Sat s regulacijom na gore (engl. <i>up regulation hour</i>)	Sat s regulacijom na dolje (engl. <i>down regulation hour</i>)
Proizvođač je u promatranom satu proizveo manje od ugovorenog	Kupuje energiju uravnoteženja po cijeni za regulaciju na gore	Kupuje energiju uravnoteženja po cijeni na spot tržištu
Proizvođač je u promatranom satu proizveo više od ugovorenog	Prodaje proizvedeni višak po cijeni na spot tržištu	Prodaje proizvedeni višak po cijeni za regulaciju na dolje

3. VJETROELEKTRANE NA TRŽIŠTU ELEKTRIČNE ENERGIJE

3.1. Trenutno stanje vjetroelektrana u Europi i svijetu


Ukupna instalirana snaga vjetroelektrana je u 2017. godini porasla za 10%, odnosno 47 GW te je do kraja godine iznosila 515 GW. Električna energija proizvedena iz vjetra na godišnjoj bazi porasla je za 17% iste godine na 1120 TWh. [3] Vidljiv je pomak u pravom smjeru budući da je još 2012. godine, samo 5 godina prije, ukupna instalirana snaga iznosila 284 GW, a proizvedena električna energija je tada bila 521 TWh. Tvrdnju da još uvijek ima mjesta za napredak podupire činjenica da današnjih 1120 TWh čini tek 4,4% ukupne svjetske proizvodnje električne energije.

Električna energija dobivena iz vjetroelektrana je postala važan dio ukupne proizvodnje električne energije u Europi. Tako je u Danskoj 2017. godine 48% od ukupno proizvedene električne energije došlo iz vjetroelektrana, dok države poput Njemačke, Portugala, Španjolske i Irske dobivaju više od 15% svoje ukupne proizvodnje iz vjetroelektrana. Kina je već neko vrijeme vodeća u svijetu po pitanju ukupne instalirane snage vjetroelektrana, 164 GW te godinu za godinom bilježe najveća povećanja (15 GW u 2017. godini). Korisno je napomenuti da iako Kina toliko prednjači sa instaliranom snagom u apsolutnom iznosu, to je svega 4% njihove ukupne instalirane snage.[3]



Slika 3.1. Ukupna instalirana snaga vjetroelektrana [3]

U Europi je dodano 16,8 GW instalirane snage iz vjetroelektrana u 2017. godini (15,6 samo EU) te ukupna instalirana snaga iznosi 177,5 GW (EU 168,7 GW). Također se u Europi najviše ulaže u izgradnju vjetroelektrana, što podržava činjenica da nova instalirana snaga iz vjetroelektrana iznosi 55% ukupnog povećanja instalirane snage. Vjetroelektrane u Europi sada zadovoljavaju 18% ukupne proizvedene električne energije. Hrvatska je bila među zemljama Europske Unije koje su imale najveći napredak u povećanju instalirane snage. Tako je u Hrvatskoj instalirana snaga vjetroelektrana povećana za 147 MW na 613 MW što pokriva oko 9% ukupne potrošnje. [4] Slika 4.2. prikazuje koliki je udio električne energije proizvedene iz vjetroelektrana u ukupnoj potrošnji električne energije za pojedinu zemlju Europe.



Slika 3.2. Udio el. energije iz VE u ukupno potrošenoj

3.2. Konkurentnost vjetroelektrana na tržištu el. energije

Davne 2008. godine EU je usvojila je paket zakona popularnog naziva 20-20-20 koji bi do 2020. trebao rezultirati 20% manjim emisijama stakleničkih plinova u odnosu na 1990., minimalno 20% udjela obnovljivih izvora energije u ukupnoj potrošnji i 20% manjom potrošnjom energije u odnosu na onu koja se do 2020. očekuje. U prethodnom poglavlju vidljivo je kako su neke zemlje već ostvarile cilj od 20% udjela obnovljivih izvora gledajući samo vjetroelektrane. Međutim, vjetroelektrane, kao i obnovljivi izvori općenito, susreću se sa poteškoćama pri stjecanju udjela na tržištu budući da su ulaganja u takve elektrane relativno velika, a proizvodnja je nerijetko nepredvidiva ili teška za prognozirati (npr. vjetroelektrane i solarne elektrane). Kako bi se potakla izgradnja elektrana na obnovljive izvore uvedeni su razni sustavi poticaja kojima je cilj povećati njihovu konkurentnost i profitabilnost te u konačnici povećanje udjela u ukupnoj proizvodnji. Kroz godine su uvedeni razni financijski poticaji koji bi vjetroelektrane i ostale obnovljive izvore učinile primamljivije investitorima, a najpoznatije među njima su:

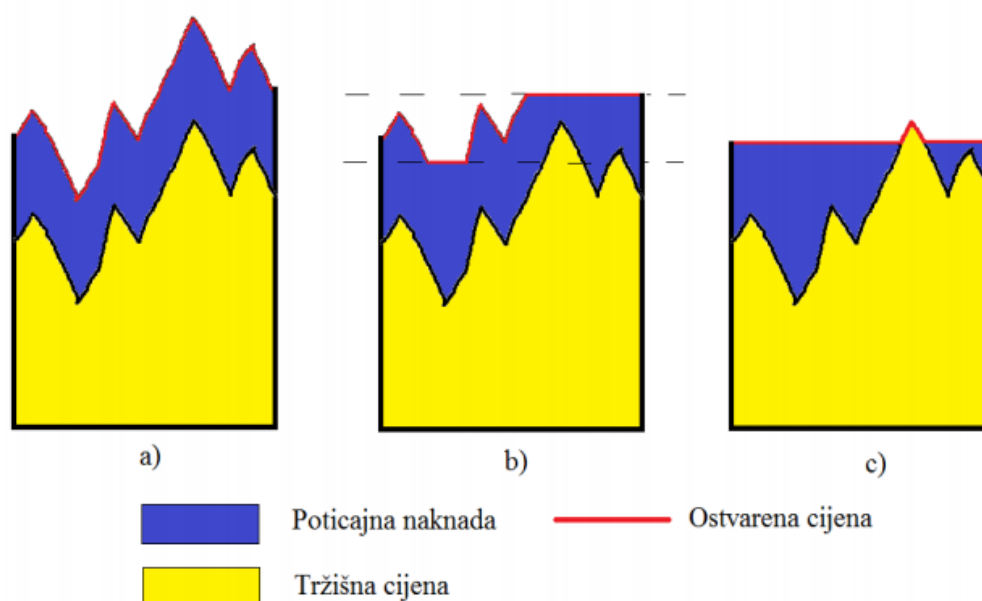
- zajamčene tarife (engl. *Feed-In tariffs*)
- zajamčene premije (engl. *Fixed premiums*)
- sustavi javnih natječaja (engl. *Tendering systems*)
- zeleni certifikati u kombinaciji s obveznim udjelom (engl. *Tradable green certificates/Quotas*)
- subvencije investicija (eng. *Investment incentives*)
- fiskalne mjere (engl. *Tax laws*) [5]

Ukratko rečeno, zajamčene tarife mogu se definirati kao zakonske regulative koje proizvođaču jamče određenu cijenu po kojoj opskrbljivač od njega otkupljuje električnu energiju. To se obično ugovara na duži niz godina. Ovakav tip poticaja je među najraširenijima u svijetu i Europi jer pruža proizvođačima sigurnost. [5] Cijena tarifa varira ovisno o obnovljivom izvoru, međutim ona može varirati i unutar određene skupine obnovljivih izvora pa su tako na primjer razlikuju tarife za vjetroelektrane na tlu od tarifa za vjetroelektrane na moru koje su znatno veće. [2] Feed-In tarife (FIT) prvo su uvedene u Njemačkoj, a potom su se proširile po drugim zemljama, uključujući i Hrvatsku. U tablici 3.1. navedene su neke od zemalja Europe koje primjenjuju zajamčene tarife i njihovi iznosi.

Tablica 3.1. Primjeri zajamčenih tarifa

ZEMLJA	IZNOS ZAJAMČENE TARIFE
Irska	VE do 5 MW: 72 €/MWh VE iznad 5 MW: 67,2 €/MWh
Češka	Fiksni iznos: 75 €/MWh
Švicarska	VE do 10 MW: 200 €/MWh VE iznad 10 MW: 200 €/MWh -nakon 5 god: 126 €/MWh

Poticaji u obliku zajamčenih premija podrazumijevaju isplatu premije za energiju iz obnovljivih izvora povrh cijene koja je postignuta na tržištu. Kao i zajamčene tarife, premije može isplaćivati operator mreže, iako se taj trošak obično prebaci na krajnje korisnike. Druga mogućnost je da država, odnosno vlada direktno isplaćuje premije proizvođaču. Također kao i kod zajamčenih tarifa, premije se razlikuju za pojedine tipove elektrana na obnovljive izvore [5].




Slika 3.3. Modeli sustava poticaja zajamčenih premija [2]

Slika 3.3. prikazuje tri modela sustava zajamčenih premija. Pod a) je prikazan model fiksnih premija, to je ujedno i najjednostavniji oblik premija. Dakle, zakonom se propiše fiksni iznos premije koji se dodaje na trenutnu tržišnu cijenu.[2] Primjer države koja slijedi ovaj primjer premija je Estonija. Estonija jamči premiju od 53,7 €/MWh za prvih 600 GWh

proizvedenih iz vjetroelektrana u toj kalendarskoj godini. Također, u Estoniji je premija fiksna za sve vrste obnovljivih izvora [6].

Ukoliko se uz neku premiju postave donja i gornja granica, dobije se slučaj kao pod b). Prednost ovog modela iz perspektive investitora, odnosno proizvođača je što donja granica premije de facto djeluje kao minimalna zajamčena cijena pa se time smanjuje rizik ulaganja. Gornja granica se postavlja kako bi se ograničio trošak poticaja kada je tržišna cijena visoka pa se u tom razdoblju smanjuje potreba za poticajem budući da je proizvodnja profitabilna. Ukoliko se dogodi slučaj da je tržišna cijena veća od postavljene gornje granice, tada cijena koju ostvaruju proizvođači odgovara toj tržišnoj cijeni. [2] Na slici 3.4. detaljnije je prikazan ovaj model premija.



Slika 3.4. Sustav poticaja sa zajamčenom premijom s gornjom i donjom granicom [2]

Posljednji od ova tri slučaja prikazan je na slici 3.3. c) i to je model sa tzv. Zajamčenom kliznom premijom (engl. *sliding premium*). Prva ju je uvela Njemačka 2012. godine ponudivši proizvođačima iz vjetroelektrana prelazak na ovakav model sa modela zajamčene tarife. Ova se premija računa na mjesečnoj bazi prema izrazu [2]:

$$\text{premija} = \text{zajamčena tarifa} - (\text{prosječna mjesečna tržišna cijena} - \text{premija menadžmenta}) \quad (3-1)$$

U suštini izraz je razlika zajamčene tarife i referentne cijene, gdje je referentna cijena definirana kao prosječna mjesečna cijena umanjena za premiju menadžmenta. Premija menadžmenta obuhvaća dodatne troškove uzrokovane izlaskom na tržište poput raznih

administrativnih troškova i sl. [2] Ovakav model danas u Europi koristi Litva, ali za male elektrane do 10 kW gdje je postavljena zajamčena tarifa od 52 €/MWh od koje se oduzima tržišna cijena za električnu energiju proizvedenu iz obnovljivih izvora energije. Dok za veće elektrane, sličan model ima Finska, gdje da bi se ostvario poticaj vjetroelektrane moraju imati minimalno 2500 MW instalirane snage. U ovom slučaju iznos premije jednak je razlici unaprijed određene ciljane cijene i prosječne tržišne cijene protekla tri mjeseca, ali važno je napomenuti da ukoliko je tržišna cijena ispod 30 € premija će se računati tako da se od ciljane cijene oduzme 30 €. Do 2015. godine ciljane cijena bila je 105,3 €/MWh dok se teži ka krajnjoj cijeni od 83,5 €/MWh. [6]

Sustav javnih natječaja funkcionira na način da država objavi javni natječaj za izgradnju vjetroelektrane na koji se javljaju potencijalni investitori ukoliko zadovoljavaju određene kriterije natječaja. Oni pritom daju ponude te kao i na svakom drugom natječaju, pobjeđuje najniža ponuda. Nakon toga taj investitor potpisuje ugovor sa državom gdje mu je zajamčena fiksna tarifa u vremenskom razdoblju na koje je ugovor potpisan. [2]

Sustav zelenih certifikata zahtjeva da opskrbljivači električne energije u svojoj ponudi imaju propisani udio, odnosno zadovoljavaju kvotu, energije iz obnovljivih izvora. Udio propisuje vlada, a opskrbljivači kao dokaz ispunjavanja kvote prikupljaju zelene certifikate koje otkupljuju od proizvođača. [5] Proizvođačima su certifikati dodijeljeni za količinu energije koju proizvedu od nezavisne strane. [7] Dakle, zeleni certifikati nisu poticajna mjera, budući da ne uključuju nikakav oblik subvencija, već regulativa kojom se obvezuje kupovina i prodaja električne energije iz obnovljivih izvora. Kazne za neuspješno ispunjavanje kvote moraju biti dovoljno velike kako bi se potaklo kupovanje certifikata, jer je financijski isplativije. [5] U ovom sustavu proizvođači električne energije iz obnovljivih izvora mogu ostvariti zaradu na dva načina, a to su [7]:

- prodajom električne energije na tržištu po tržišnoj cijeni
- prodajom zelenih certifikata opskrbljivačima


Subvencije investicija uvode se kako bi se ublažio teret početnih ulaganja u obnovljive izvore te time stimulirala izgradnja takvih elektrana. Najčešći primjeri su subvencioniranje početnih troškova ili krediti s niskim kamatnim stopama. [2]

Fiskalne mjere obuhvaćaju olakšice kroz smanjene poreze na el. energiju, manje poreze na emisije, snižene stope PDV-a te u nekim slučajevima oslobođenje od plaćanja poreza. [7]

4. ELEKTRANE NA BIOMASU NA TRŽIŠTU ELEKTRIČNE ENERGIJE

Gledajući samo obnovljive izvore, danas se najviše električne energije proizvede u vjetroelektranama i solarnim elektranama. Elektrane na biomasu predstavljaju 18% energije proizvedene iz obnovljivih izvora u Europskoj uniji. [8] Za razliku od trenutno dominantnijih i ranije spomenutih vjetroelektrana i solarnih elektrana, elektrane na biomasu nude predvidivost i planiranje proizvodnje, karakteristiku koja je teško ostvariva kada je izvor energije sunce ili vjetar. U svijetu se sve više teži ka povećanju energije iz obnovljivih izvora, zbog toga će biomasa i elektrane na biomasu imati rastuću ulogu u proizvodnji električne energije.

Njemačka je zemlja s uvjerljivo najviše energije iz biomase u Europskoj uniji te čini 30% u ukupnoj proizvodnji. Iza nje je Velika Britanija sa 14%. Slika 4.1. prikazuje najveće udjele zemalja u Europskoj uniji u proizvodnji električne energije iz biomase.[8]



Slika 4.1. Udio zemalja u ukupnoj proizvodnji el. energije iz biomase u EU

Budući da električna energija proizvedena od biomase također spada u obnovljive izvore energije, svi poticaji navedeni u prethodnom poglavlju odnose se i na nju. Međutim, moguće je da pojedina zemlja ima dodatne uvjete kako bi se elektrana kvalificirala za određeni poticaj (min./max. instalirana snaga, određena učinkovitost i sl.).

Na tablici 4.1. prikazano je nekoliko zemalja sa vrstama poticaja i iznosima istih za elektrane na biomasu te uvjeti koje elektrana mora zadovoljiti.

Tablica 4.1. Primjeri poticaja za elektrane na biomasu

ZEMLJA	VRSTA POTICAJA	IZNOS POTICAJA	UVJET
Austrija	Zajamčena tarifa	105-220 €/MWh	Učinkovitost > 60%
Finska	Zajamčena premija	83,5 €/MWh	Elektrane koje koriste pelete ako prije nisu primale poticaj i sa instaliranom snagom min. 100 kVA
Njemačka	Zajamčene tarife	57,1-133,2 €/MWh	Dokaz o vrsti korištenog biogoriva
	Zajamčene premije		
Irska	Zajamčene tarife	147 €/MWh	Kogeneracijske do 1.5 MW
		126 €/MWh	Kogeneracijske iznad 1.5 MW
		99,8 €/MWh	Elektrane koje koriste poljoprivredne usjeve kao gorivo
		89,1 €/MWh	Ostale

5. MATEMATIČKI MODEL SUSTAVA

Dio matematičkog modela je preuzet iz diplomskog rada „*Optimalna ponuda elektrane na biomasu na tržištu električne energije*“ [9]. Model je nadograđen za potrebe ovog rada budući da se razmatra slučaj raspolaganja elektranom na biomasu i vjetroelektranama.

5.1. Realizacija modela

Funkcija cilja osmišljena je kako bi se maksimizirao prihod prilikom prodaje električne energije koji se potom umanjuje za iznose graničnih troškova proizvodnje te troškova pokretanja. [9]

$$\text{maks.} \sum_{t=1}^{24} \left(\lambda_t (p_t - k_t) - \sum_{e=1}^{n_e} (\beta_e G_{e,t} + C_e'''' s_{e,t}'''' + C_e'''' s_{e,t}'''' + C_e''' s_{e,t}''' + C_e'' s_{e,t}'' + C_e' s_{e,t}') \right) \quad (5 - 1)$$

U gornjoj jednadžbi je [9]:

- t - trenutni sat
- λ_t - cijena električne energije za „t“ sat
- p_t - količina prodane električne energije na tržištu za „t“ sat
- k_t - količina kupljene električne energije na tržištu za „t“ sat
- e - oznaka elektrane
- β_e - granični troškovi proizvodnje el. energije u elektrani „e“ u ovisnosti o vrijednosti proizvodnje
- $G_{e,t}$ - proizvedena električna energija u „e“ elektrani za „t“ sat
- C_e'''' - trošak pokretanja „e“ elektrane pete ili više sati nakon prestanka rada
- $s_{e,t}''''$ - pokretanje „e“ elektrane u „t“ satu pet ili više sati nakon prestanka rada
- C_e''' - trošak pokretanja „e“ elektrane četiri sata nakon prestanka rada
- $s_{e,t}'''$ - pokretanje „e“ elektrane u „t“ satu četiri sata nakon prestanka rada
- C_e'' - trošak pokretanja „e“ elektrane tri sata nakon prestanka rada
- $s_{e,t}''$ - pokretanje „e“ elektrane u „t“ satu tri sata nakon prestanka rada
- C_e' - trošak pokretanja „e“ elektrane dva sata nakon prestanka rada
- $s_{e,t}'$ - pokretanje „e“ elektrane u „t“ satu dva sata nakon prestanka rada
- C_e' - trošak pokretanja „e“ elektrane jedan sat nakon prestanka rada
- $s_{e,t}'$ - pokretanje „e“ elektrane u „t“ satu jedan sat nakon prestanka rada

5.2. Ograničenja modela

Kod planiranja rada elektrane potrebno je uzeti u obzir da promjene u količini pogonskog goriva neće imati trenutni utjecaj na proizvodnju električne energije. Brzina kojom će elektrana reagirati na navedenu promjenu prvenstveno ovisi o veličini iste. [9]

5.2.1. Troškovi pokretanja

Termoelektrane, a samim time i elektrane na biomasu, zahtijevaju određenu količinu goriva pri pokretanju proizvodnje ili zbog sprječavanja potencijalnih oštećenja. Iz toga se razloga elektranama uz postojeću gornju granicu, koja je određena instaliranom snagom, odrađuje i donja granica proizvodnje [9].

Razmotri li se elektrana koja radi u određenom satu, gornja granica proizvodnje bit će jednaka instaliranoj snazi te elektrane. Analogno tomu, ukoliko ne radi, granica će biti nula. To je vidljivo u sljedećem izrazu:

$$G_{e,t} \leq u_{e,t} * G_{max,e} \quad (5 - 2)$$

gdje je:

- $G_{e,t}$ - količina električne energije proizvedene u „e“ elektrani u „t“ satu
- $u_{e,t}$ - faktor istinitosti pogonskog stanja „e“ elektrane u „t“ satu (1 ako je u pogonu, 0 ako nije)
- $G_{max,e}$ - maksimalna proizvodnja „e“ elektrane za sat „t“

Uvodi se binarna varijabla $u_{e,t}$ koja određuje pogonsko stanje elektrane, odnosno radi li elektrana u promatranom satu ili ne. Pomoću iste varijable, moguće je odrediti i donju granicu elektrane:

$$G_{e,t} \geq u_{e,t} * G_{min,e} \quad (5 - 3)$$

gdje je:

- $G_{e,t}$ - minimalna proizvodnja „e“ elektrane u „t“ satu

Za slučaj pogonskog stanja donja granica jednaka je $G_{min,e}$, dok je za slučaj kada elektrana nije u pogonu ona nula.

Iz svega navedenog, može se zaključiti da vrijedi:

$$\begin{aligned} u_{e,t} = 1 & \quad G_{e,t} = [G_{min,e}, G_{max,e}] \\ u_{e,t} = 0 & \quad G_{e,t} = 0 \end{aligned}$$

Ranije je već spomenuto kako elektrane na biomasu prilikom pokretanja imaju određene troškove. Razlog tomu je jer se dio pogonskog goriva troši na zagrijavanje elektrane do radne temperature. Potrebna količina goriva za zagrijavanje ovisit će o temperaturi elektrane u trenutku pokretanja, a ta će temperatura ovisiti o količini vremena koje je proteklo od prestanka rada elektrane. Takve troškove moguće je izraziti na sljedeći način [9]:

$$C_e'''' = \left(1 - e^{-\frac{4}{\tau}}\right) C_e'''''' \quad (5 - 4)$$

$$C_e''' = \left(1 - e^{-\frac{3}{\tau}}\right) C_e'''''' \quad (5 - 5)$$

$$C_e'' = \left(1 - e^{-\frac{2}{\tau}}\right) C_e'''''' \quad (5 - 6)$$

$$C_e' = \left(1 - e^{-\frac{1}{\tau}}\right) C_e'''''' \quad (5 - 7)$$

gdje je:

- C_e'''''' - trošak pokretanje nakon pet ili više sati izvan pogona
- C_e'''' - trošak pokretanje nakon minimalno četiri sata izvan pogona
- C_e''' - trošak pokretanje nakon minimalno tri sata izvan pogona
- C_e'' - trošak pokretanje nakon minimalno dva sata izvan pogona
- C_e' - trošak pokretanje nakon minimalno jedan sat izvan pogona
- τ - vremenska termalna konstanta

Ukoliko će elektrana biti jako kratko izvan pogona, može se dogoditi da je isplativije ne zaustavljati izgaranje iako se ne proizvodi električna energija. U tom se slučaju količina goriva održava neznatno iznad količine koja je potrebna za održavanje radne temperature. Pretpostavka je da je ta količina goriva konstantna pa su zbog toga troškovi pokretanja proporcionalni vremenu koje je elektrana provela izvan pogona [9]:

$$C_{pok} = C_{pohra.} \cdot t \quad (5 - 8)$$

Za prikazivanje pokretanja svake elektrane nakon određenog vremena izvan pogona koristi se pet varijabli pa je potrebno uvesti ograničenja kako bi se osigurala ispravnost varijable pokretanja [9]:

$$u_{g,t} - u_{g,t-1} - u_{g,t-2} - u_{g,t-3} - u_{g,t-4} - u_{g,t-5} - s_{g,t}'''' \quad (5 - 9)$$

$$u_{g,t} - u_{g,t-1} - u_{g,t-2} - u_{g,t-3} - u_{g,t-4} - u_{g,t-5} - s_{g,t}'''' \quad (5 - 10)$$

$$u_{g,t} - u_{g,t-1} - u_{g,t-2} - u_{g,t-3} - u_{g,t-4} - u_{g,t-5} - s_{g,t}''' \quad (5 - 11)$$

$$u_{g,t} - u_{g,t-1} - u_{g,t-2} - u_{g,t-3} - u_{g,t-4} - u_{g,t-5} - s_{g,t}'' \quad (5 - 12)$$

$$u_{g,t} - u_{g,t-1} - u_{g,t-2} - u_{g,t-3} - u_{g,t-4} - u_{g,t-5} - s_{g,t}' \quad (5 - 13)$$

5.2.2. Ograničenje ravnoteže pogonskog goriva

Ograničenje pogonskog goriva uvodi se kako količina biomase ne bi premašila volumen spremnika [9]:

$$S_{e,t} = S_{e,t-1} + V_{e,t} - P_{e,t} - s'_{e,t} \cdot P_{start,1} - s''_{e,t} \cdot P_{start,2} - s'''_{e,t} \cdot P_{start,3} - s''''_{e,t} \cdot P_{start,4} - s''''_{e,t} \cdot P_{start,5} \quad (5 - 14)$$

$$G_{e,t} = P_{e,t} \cdot \mu_e \quad (5 - 15)$$

gdje je :

$S_{e,t}$	-količina biomase u spremniku generatora „e“ u satu „t“
$S_{e,t-1}$	-količina biomase u spremniku generatora „e“ n kraju prethodnog sata
$V_{e,t}$	-dobavljena količina biomase u spremnik „e“ generatora u satu „t“
$P_{e,t}$	-količina potrošene biomase na generatoru „e“ u satu „t“
$s'_{e,t}$	-pokretanje „e“ elektrane u „t“ satu jedan sat nakon prestanak rada
$P_{start,1}$	-količina goriva potrebnog za pokretanje jedan sat nakon prestanka rada
$s''_{e,t}$	-pokretanje „e“ elektrane u „t“ satu dva sata nakon prestanka rada
$P_{start,2}$	-količina goriva potrebnog za pokretanje dva sata nakon prestanka rada
$s'''_{e,t}$	-pokretanje „e“ elektrane u „t“ satu tri sata nakon prestanka rada
$P_{start,3}$	-količina goriva potrebnog za pokretanje tri sata nakon prestanka rada
$s''''_{e,t}$	-pokretanje „e“ elektrane u „t“ satu četiri sata nakon prestanka rada
$P_{start,4}$	-količina goriva potrebnog za pokretanje četiri sata nakon prestanka rada
$s''''_{e,t}$	-pokretanje „e“ elektrane u „t“ satu pet ili više sati nakon prestanka rada

$P_{start,5}$ -količina goriva potrebnog za pokretanje pet ili više sata nakon prestanka rada

Izrazom 4-15 opisana je veza između količine biomase u tonama i proizvedene električne energije u MWh pomoću koeficijenta μ_e . Tablica 5.1. prikazuje vrijednosti koeficijenta za nekoliko goriva. Ogrjevne vrijednosti preko kojih se matematički dođe do koeficijenta μ_e preuzete su sa [10].

Tablica 5.1. Vrijednosti koeficijenta μ_e za pojedino gorivo

TIP GORIVA	ORJEVNA MOĆ [MJ/kg]	μ_e
Suho drvo	18,5	2,05
Peleti	16,9	1,88
Cjepanice	14,4	1,6
Drvena sječa	12,2	1,35
Pšenična slama	17,2	1,91

5.2.3. Dodatna ograničenja

Ograničenja za vrijeme proizvodnje opisana su na sljedeći način:

$$G_{e,t} - u_{e,t} \cdot G_{max,e} \leq 0 \quad (5 - 16)$$

$$u_{e,t} \cdot G_{min,e} - G_{e,t} \leq 0 \quad (5 - 17)$$

Potrebno je također dodati ograničenje ravnoteže opterećenja zbog usklađivanja proizvedene i kupljene električne energije elektrane sa vrijednosti bilateralnog ugovora i prodanom energijom na tržištu [9]:

$$\sum_{e=1}^{n_e} G_{e,t} + \sum_{w=1}^{n_w} G_{w,t} + k_t = B_t + p_t \quad (5 - 18)$$

gdje je :

- $G_{e,t}$ - proizvodnja električne energije u elektrani na biomasu „e“ za „t“ sat
- $G_{w,t}$ - proizvodnja električne energije u vjetroelektrani „w“ za „t“ sat
- k_t - kupljena električna energija na tržištu za „t“ sat
- B_t - prodana električna energija na tržištu s bilateralnim ugovorom za „t“ sat
- p_t - prodana električna energija na tržištu za „t“ sat

Naposljetku, uvode se ograničenja varijabli [9]:

$$u_{e,t} \in \{0,1\} \quad (5 - 19)$$

$$s_{e,t}'''' \in \{0,1\} \quad (5 - 20)$$

$$s_{e,t}'''' \in \{0,1\} \quad (5 - 21)$$

$$s_{e,t}''' \in \{0,1\} \quad (5 - 22)$$

$$s_{e,t}'' \in \{0,1\} \quad (5 - 23)$$

$$s_{e,t}' \in \{0,1\} \quad (5 - 24)$$

$$0 \leq k_t \quad (5 - 25)$$

$$0 \leq p_t \quad (5 - 26)$$

$$0 \leq S_{e,t} \leq S_{e,max} \quad (5 - 27)$$

5.3. Model minimalizacije gubitaka penala zbog uzrokovane neravnoteže

Drugi model izrađen je na temeljima prvoga, a glavna razlika je u funkciji cilja. Dok je u prvom modelu funkcija cilja osmišljena zbog maksimiziranja zarade, kod ovoga je modela funkcija cilja osmišljena kako bi se minimizirali gubici u slučaju promjene očekivane proizvodnje vjetroeletana, odnosno, pojave manjka ili viška proizvedene električne energije iz vjetroeletana.

$$\begin{aligned} \min. \sum_{t=1}^{24} (E_{dod,t} * P_{en+} * \lambda_t + E_{visak,t} * \lambda_t * (1 - P_{en-}) + \\ \sum_{e=1}^{n_e} (\beta_e G_{e,t} + C_e'''' s_{e,t}'''' + C_e'''' s_{e,t}'''' + C_e''' s_{e,t}''' + C_e''' s_{e,t}''' + C_e'' s_{e,t}'' + C_e' s_{e,t}')) \end{aligned} \quad (5 - 28)$$

gdje je:

t - trenutni sat

λ_t - cijena električne energije za „ t “ sat

$E_{dod,t}$ - manjak električne energije u „ t “ satu

P_{en+} - koeficijent penalizacije cijene pri kupovini manjka električne energije

$E_{visak,t}$ - višak električne energije u „t“ satu

P_{en-} - koeficijent penalizacije cijene pri prodaji viška električne energije

Drugi dio funkcije cilja jednak je kao i kod (5-1). Također, vrijede sva ograničenja kao i za funkciju prvog modela. Jedina razlika je u (5-18) te je za ovaj model to ograničenje opisano sljedećim izrazom:

$$\sum_{e=1}^{n_e} G_{e,t} + \sum_{w=1}^{n_w} G_{w,t} + E_{dod,t} - E_{visak,t} = B_t + P_{da,t} \quad (5 - 29)$$

U ovom izrazu su sadržane i količina električne energije koja se kupuje pri manjoj proizvodnji od planirane, odnosno količina koja se prodaje pri proizvodnji većoj od planirane. $P_{da,t}$ ovdje predstavlja ulazni podatak koji se dobije kao rezultat prethodnog modela (za prodanu energiju vrijednost će biti pozitivnog, a za kupljenu negativnog predznaka).

6. PROVOĐENJE MATEMATIČKOG MODELA

6.1. Izračun i unos početnih parametara

Za potrebe simulacija svih navedenih slučajeva osmišljen je proizvodni sustav u sastavu od tri elektrane na biomasu i dvije vjetroelektrane. Iznosi instaliranih snaga dani su u tablici 6.1.


Tablica 6.1. Instalirana snaga elektrana u sustavu

ELEKTRANA	INSTALIRANA SNAGA [MW]
Biomasa 1	3,3
Biomasa 2	8,6
Biomasa 3	4,6
VE 1	5,95
VE 2	17,5

Cijene električne energije koje su korištene u simulaciji su preuzete sa Cropex tržišta električne energije na dan 15.08.2018.

Tablica 6.2. Cijena električne energije na dan 15.08.2018. [11]

t [h]	1	2	3	4	5	6	7	8	9	10	11	12
λ_t [€]	51,9	49,82	48,26	46,01	44,43	46,05	49,32	53,14	58,25	57,85	53,69	54,4
t [h]	13	14	15	16	17	18	19	20	21	22	23	24
λ_t [€]	52,23	51,9	51	51,9	51,9	53	62,21	64,28	65	64,83	63,83	55,75



Slika 6.1. Dnevni dijagram cijene električne energije

Iz izraza (5-4), (5-5), (5-6), (5-7) i (5-8) dobiveni su troškovi pokretanja za pojedine elektrane na biomasu te su prikazani u tablici:

Tablica 6.3. Troškovi pokretanja

	Biomasa 1	Biomasa 2	Biomasa 3
C_g'''' [EUR]	796	1318	1107
C_g'''' [EUR]	688	1140	958
C_g''' [EUR]	621	1020	864
C_g'' [EUR]	500	815	689
C_g' [EUR]	310	510	432

Također, izračunate su količine pogonskog goriva koje je potrebno za pokretanje pojedine elektrane na biomasu. Rezultati su vidljivi u donjoj tablici.

Tablica 6.4. Količina pogonskog goriva potrebnog za pokretanje

	Biomasa 1	Biomasa 2	Biomasa 3
$P_{start,5}$ [t]	5,9	15,5	8,2
$P_{start,4}$ [t]	5,1	13,4	7,1
$P_{start,3}$ [t]	4,6	12	6,4
$P_{start,2}$ [t]	3,7	9,6	5,1
$P_{start,1}$ [t]	2,3	6	3,2

Naposljetku, uneseni su granični troškovi proizvodnje za svaku od elektrana koji su dani u tablici 6.5.


Tablica 6.5. Granični troškovi proizvodnje

	β_g [MW/MWh]
Biomasa 1	72
Biomasa 2	63
Biomasa 3	72

Simulirana su ukupno tri slučaja, a svaki od slučajeva sadrži rezultate dva modela. Prvi model nastoji maksimizirati dobit uz poznatu prognozu proizvodnje iz vjetroelektrana. To u stvarnosti odgovara vremenu do 10h prethodnoga dana, do kada se predaju ponude za tržište za dan unaprijed. Za drugi model pretpostavljeno je da se kasnije u danu zbog promijene prognoze vjetra proizvodnja iz vjetroelektrana promijenila. Tada model nastoji minimalizirati troškove tako što računa isplati li se promjenu očekivane proizvodnje regulirati elektranama na biomasu ili je pak isplativije platiti tržišne penale zbog uzrokovanja neravnoteže.

6.2. Simulacija za slučaj bez premija

Prva simulacija razmatra slučaj u kojemu proizvođač električne energije ima potpisan bilateralni ugovor koji ga obavezuje na proizvodnju 7 MWh električne energije za svaki sat u danu. Ugovorena cijena bilateralnog ugovora je 75 €/MWh. Međutim, proizvođač u ovom slučaju nije ostvario prava na dodatne financijske poticaje te svoju energiju prodaje po cijeni koju ostvari na tržištu.




Slika 6.2. Očekivana proizvodnja vjetroelektrana


Na gornjoj slici prikazane su prve prognozirane vrijednosti proizvodnje za obje vjetroelektrane. Te su vrijednosti unesene u model kao ulazni podatak, a ne kao varijabla. Model će računati treba li paliti elektrane na biomasu, odnosno je li to uopće isplativo.

Usporedbom cijene i graničnih troškova elektrana na biomasu u pojedinom satu, može se zaključiti kako elektrane na biomasu neće raditi budući da cijena gotovo cijeli dan ne prelazi granične troškove, a slika 6.3. to i potvrđuje. Iako je cijena prešla granični trošak elektrane 2 na svega par sati, potrebno je uzeti u obzir kako elektrana tada ima vrlo visoke

troškove pokretanja budući da je izvan pogona više od 5 sati, a proizvodnja bi bila isplativa svega 3 sata stoga paljenje uistinu nije isplativo.




Slika 6.3. Usporedba tržišne cijene i graničnih troškova



Slika 6.4. Angažiranost elektrana promatranog sustava za prvi slučaj


Slikom 6.4. prikazane su aktivnosti pojedinih elektrana promatranog proizvodnog sustava za slučaj bez financijskih poticaja i s vrijednosti bilateralnog ugovora 7 MWh. Vidljivo je iz slike kako u ovom slučaju elektrane na biomasu nisu upaljene tijekom cijelog dana. To je očekivani ishod budući da cijena u niti jednom satu ne prelazi granične troškove proizvodnje elektrana, a vjetroelektrane proizvode dovoljno kako bi zadovoljili potrebe bilateralnog ugovora. Slika 6.5. prikazuje prodanu električnu energiju na tržištu povrh bilateralnog ugovora. Detaljnijom analizom slika 6.4. i 6.5. moguće je zaključiti kako je ispunjen uvjet opisan izrazom (5-18) budući da ukupna proizvedena električna energije (u

ovom slučaju samo iz vjetroelektrana), odgovara sumi energije prodane bilateralnim ugovorom i energije prodane na tržištu.



Slika 6.5. Ukupna prodana električna energija

Nakon ovoga, dobiveni rezultat „ P_{da} “ se kao ulazni podatak ubacuje u model za minimalizaciju gubitaka zajedno sa drugom prognozom proizvodnje vjetroelektrana (slika 6.6.).



Slika 6.6. Nova prognozirana proizvodnja vjetroelektrana


Model nastoji održati troškove, odnosno gubitke minimalnima, a da pri tome izraz (5-29) ostane istinit. Budući da je P_{da} ulazni podatak, to znači da je desna strana izraza konstantna pa kako bi istinitost izraza ostala nepromijenjena, model upravlja varijablama s lijeve strane jednakosti. Moguća rješenja biti će regulacija proizvodnje elektranama na

biomasu ili kupovina manjka električne energije, odnosno prodaja viška. Potrebno je naglasiti kako se prodaja viška i kupovina manjka vrši po posebnim cijenama jer se primjenjuju koeficijenti penalizacije na tržišnu cijenu. Ti koeficijenti su sljedeći i oni iznose:


- za višak: $P_{en-} = 0,1$
- za manjak: $P_{en+} = 2$

Također je potrebno naglasiti kako pri proizvedenom višku, proizvođač nema gubitak u pravom smislu te riječi, već se radi o tzv. oportunitetnom trošku. Razlog tomu je da proizvođač ipak ima prihod, međutim prodaja se vrši po cijeni od 10% tržišne cijene (dakle, ostvaruje gubitak od 90% tržišne cijene koju bi dobio da je pravilno prognozirao proizvodnju iz vjetroelektrana u trenutku davanja ponude na tržištu dan unaprijed).

Slikom 6.7. prikazane su ukupne očekivane proizvodnje iz vjetroelektrana za obje prognoze. Ukoliko proizvodnja vjetroelektrana bude manja od prvobitno očekivane, nastaje manjak električne energije. Potrebno je nadomjestiti taj manjak povećanjem proizvodnje elektranama na biomasu ili kupiti električnu energiju po većoj cijeni zbog penala. Na slici 6.8. uočljivo je da je u ovom slučaju uključena elektrana 2 na biomasu te se njome nadomjestio nastali manjak u satima 1-9. Ta elektrana i dalje nije isplativa (Slika 6.3.), međutim gubitak koji se ostvaruje po MWh električne energije je znatno manji od kupovanja električne energije po cijeni s penalom ($2\lambda_t$).




Slika 6.7. Krivulje prve i druge prognoze očekivane proizvodnje VE




Slika 6.8. Angažiranost elektrana promatranog sustava pri novoj očekivanoj proizvodnji VE

Suprotan slučaj bio bi kada nastane višak u proizvodnji. Idealno rješenje bilo bi jednostavno smanjiti proizvodnju elektrana na biomasu, međutim elektrane na biomasu su već bile izvan pogona, osim BM2 koja je radila samo da nadomjesti manjak. Tada je proizvođač prisiljen prodavati taj višak, ali po penaliziranoj cijeni ($0,1\lambda_t$) čime ostvaruje ranije spomenuti


oportunitetni trošak. Opisana situacija prikazana je slikom 6.9, dok slika 6.10. prikazuje ukupne ostvarene prihode i rashode promatranog proizvodnog sustava za ovaj slučaj.



Slika 6.9. Količine manjka i viška električne energije za pojedini sat



Slika 6.10. Prihodi i rashodi promatranog sustava – prvi slučaj




Slika 6.11. Zarada po satu i kumulativna zarada promatranog sustava – prvi slučaj

6.3. Simulacija za slučaj sa premijom


U ovom slučaju razmatra se scenarij u kojemu je proizvođaču zajamčena fiksna premija u iznosu od 20 € na tržišnu cijenu za cijeli proizvodni sustav, bez razlika među tipovima elektrana, za cijeli promatrani proizvodni sustav. Bilateralni ugovor jednak je kao i u prvoj simulaciji ($B_t = 7$ MWh po cijeni od 75 €/MWh). Ulazni podaci proizvodnje vjetroelektrana za obje očekivane proizvodnje ostaju jednaki te su prikazani slikom 6.7.

Pogledom na sliku 6.12. primjetna je posljedica premija, proizvodnja druge elektranom je isplativa tijekom cijelog dana, dok su druge dvije elektrane isplative većim dijelom. Dakle, može se očekivati veća angažiranost elektrana te samim time više prodane energije na tržištu povrh bilateralnog ugovora.




Slika 6.12. Usporedba graničnih troškova elektrana na biomasu i cijene s premijom

Slika 6.13. potvrđuje prethodna očekivanja budući da druge elektrane na biomasu radi cijeli dan. Iz prethodne slike moguće je bilo zaključiti da prva i treća elektrana nisu isplative u svakom satu čak i uz premije, međutim zbog velikih troškova pokretanja proizvođaču je isplativije držati ih upaljenima u tim satima nego ih gasiti pa paliti u satima kada su one isplative. Zbog toga te dvije elektrane u satima neisplative proizvodnje rade svaka na svojem tehničkom minimumu.



Slika 6.13. Angažiranost elektrana na biomasu za drugi slučaj


Kako je ranije spomenuto, veća angažiranost elektrana na biomasu rezultirat će većom proizvodnjom te je time znatno više električne energije prodano na tržištu u svakom satu, što slika 6.14. potvrđuje.



Slika 6.14. Ukupna prodana električna energija za drugi slučaj


Kao i u prvom slučaju, pretpostavlja se da je krajem dana stigla nova prognoza očekivane proizvodnje vjetroelektrana za sljedeći dan te se vrijednost P_{da} unosi u drugi model zajedno sa novom očekivanom proizvodnjom VE.

Zbog velikih penala zbog uzrokovanja neravnoteže za očekivati je da će model nastojati svaku promjenu regulirati elektranama na biomasu. Na slici 6.15. moguće je primijetiti kako se upravo to dogodilo. Budući da je proizvodnja VE u prvih 9 sati manja od prvobitnih očekivanja, proizvodnja elektrana 1 i 3 iz biomase je povećana unatoč neprofitabilnoj proizvodnji jer je kao i u prvom slučaju taj ishod financijski manje štetan od kupovine el. energije po dvostruko većoj cijeni.




Slika 6.15. Angažiranost elektrana na biomasu nakon nove prognoze za VE

Nova očekivana proizvodnja još je uvijek manja u satima 8 i 9, međutim tada su sve elektrane radile maksimalnim kapacitetom i prije nove prognoze. Zbog toga se nema odakle nadoknaditi nastali manjak u ovim satima. Događa se suprotan slučaj onome iz prošlog poglavlja gdje proizvođač nije mogao dodatno smanjiti proizvodnju budući da su elektrane već bile izvan pogona. U ovom slučaju ne može dodatno povišiti proizvodnju pa je prisiljen kupiti potrebnu energiju po penaliziranoj cijeni (Slika 6.16.).




Slika 6.16. Količina manjka i viška električne energije za drugi slučaj

Viša ostvarena cijena zbog premija uzrokovala je veći angažman proizvodnih kapaciteta te veću proizvodnju električne energije što je rezultiralo osjetno većim prihodima, odnosno zaradom (Slika 6.17. i 6.18.).



Slika 6.17. Prihodi i rashodi promatranog sustava – drugi slučaj




Slika 6.18. . Zarada po satu i kumulativna zarada promatranog sustava – drugi slučaj


6.4. Simulacija za slučaj sa premijom i bilateralnim ugovorom od 20 MWh

U trećem slučaju povećana je vrijednost bilateralnog ugovora tako da bude gotovo uvijek veća od proizvodnje VE. Nova vrijednost ugovora je 20 MWh, dok je cijena ostala 75 €/MWh.


Budući da se u ovom slučaju radi o istim cijenama s premijom kao i u prošlom slučaju, isplativost elektrana na biomasu te njihovi angažmani su jednaki. Primjetna razlika je u raspodjeli prodane energije, odnosno količini koja je prodana preko bilateralnih ugovora i količine koja je prodana na tržištu (Slika 6.19.). Druga razlika je u ukupnim prihodima koji su malo veći u odnosu na prethodni slučaj (Slika 6.20.). To je rezultat većeg bilateralnog ugovora jer se više energije prodaje po većoj cijeni.



Slika 6.19. Ukupna prodana električna energija za treći slučaj



Slika 6.20. Prihodi i rashodi promatranog sustava – treći slučaj



Slika 6.21. Zarada po satu i kumulativna zarada promatranog sustava – treći slučaj

7. ZAKLJUČAK

Obnovljivi izvori energije iz godine u godinu zauzimaju sve veći udio u ukupnoj količini proizvedene električne energije, kako u Europi, tako i u svijetu. Međutim, mjesta za napredak ima još mnogo prije nego se svijet bude mogao u potpunosti osloniti na njihovu proizvodnju. U ovom radu, posebice u analizi simulacija, vidljiva su dva problema s kojima se određeni oblici obnovljivih izvori susreću, a to su nepouzdanost proizvodnje te neisplativost bez dodatnih poticaja.

Tri simulirana slučaja u ovom radu jasno pokazuju kako elektrane na biomasu teško mogu biti konkurentne i ostvarivati zaradu bez dodatnih financijskih poticaja. Ulazni troškovi goriva te troškovi pokretanja su preveliki. U teorijskom dijelu rada spomenuto je kako će elektrane na biomasu imati važnu ulogu u budućnosti proizvodnje električne energije upravo zbog mogućnosti reguliranja proizvodnje, što se u simuliranim slučajevima pokazalo kao vrlo korisna odlika. Idealni slučaj za proizvođača je da elektrana na biomasu radi neprekidno zbog njenih visokih troškova pokretanja jer ukoliko ona ne radi, proizvođač nema koristi od mogućnosti njezinog reguliranja. Zbog toga su drugi i treći slučaj bili znatno isplativiji za proizvođača budući da je većinu promjena bilo moguće regulirati elektranama na biomasu te nije bilo potrebe za kupovinom ili prodajom energije po penaliziranim cijenama. Iako nije bio jednako isplativ, prvi slučaj nije toliko vjerojatan u stvarnosti budući da većina zemalja ima neki tip olakšica ili poticaja za pojedini oblik obnovljivih izvora energije.

Trenutno većina obnovljivih izvora energije nisu isplativa bez dodatnih poticaja, međutim to se nastoji promijeniti s vremenom. Očekivan je nastavak rastućeg trenda povećanja udjela obnovljivih izvora u ukupnoj proizvedenoj električnoj energiji. Time će se zemlje sve više oslanjati na njih za opskrbu svojih energetske potrebe što bi trebalo rezultirati u povećanju njihove isplativosti neovisno o poticajima.

Literatura

- [1] Nikolovski, S; Fekete K; Knežević, G. i Stanić Z. Uvod u tržište električne energije. Osijek: ETFOS, 2010.
- [2] Knežević, G. Optimalna zajednička ponuda na tržištu električne energije za sustav hidroelektrana i vjetroelektrana, doktorski rad, 2013.
- [3] Wind energy, dostupno online: <https://www.bp.com/en/global/corporate/energy-economics/statistical-review-of-world-energy/renewable-energy/wind-energy.html> (pristup 25.07.2018.)
- [4] Wind in power 2017, dostupno online: <https://windeurope.org/wp-content/uploads/files/about-wind/statistics/WindEurope-Annual-Statistics-2017.pdf> (pristup 25.07.2018.)
- [5] Barney, A. Making the most of wind: a business perspective on subsidy system sin France, Germany and Sweden, Gotland University, 2012., dostupno online: <https://www.diva-portal.org/smash/get/diva2:691556/FULLTEXT01.pdf> (pristup 02.08.2018.)
- [6] RES Legal, dostupno online: <http://www.res-legal.eu/home/> (pristup 03.08.2018.)
- [7] Ognjan, D. Poticajne mjere za proizvodnju električne energije iz biomase-usporedba mjera u Hrvatskoj i Europi, dostupno online: <http://www.ho-cired.hr/referati/SO4-14.pdf> (pristup 03.08.2018.)
- [8] Bioenergy insight – Bioheat, Biopower, Biofuel, dostupno online: <http://www.aebiom.org/bioenergy-insight-bioheat-biopower-biofuel/> (pristup 03.08.2018.)
- [9] Ivanković, D. Optimalna ponuda elektrane na biomasu na tržištu električne energije, Osijek: FERIT, 2018.
- [10] Priručnik o gorivima iz drvne biomase, dostupno online: http://www.regea.org/assets/files/objavilismo2012/D32_Biofuel_hanbook_REGEA.pdf (pristup 04.09.2018.)
- [11] Hrvatska burza električne energije, dostupno online: <https://www.cropex.hr/hr/> (pristup 05.09.2018.)

Životopis

Marin Medved rođen je u Našicama 28.12.1993. godine. Osnovnu školu pohađao je u Zdencima. 2008. godine upisuje se u Srednju školu Isidora Kršnjavog u Našicama, smjer tehničar za elektroniku. Po završetku srednje škole 2012. godine, upisuje preddiplomski studij na Elektrotehničkom fakultetu u Osijeku. Ljetni semestar akademske godine 2015./2016. proveo je na studentskoj razmjeni u Bremenu u Njemačkoj. Nakon toga, 2016. godine upisuje se na diplomski studij, smjer elektroenergetski sustavi.

Sažetak

Ovaj rad definira tržište električne energije te opisuje penalizaciju tržišnih sudionika uslijed uzrokovanja neravnoteže tržišta. Razmotrene su vjetroelektrane i elektrane na biomasu, odnosno njihova zastupljenost u ukupnoj proizvodnji te sustavi poticaja kojima one podliježu. Na kraju su opisana dva matematička modela koji su u programskom paketu MATLAB korišteni za potrebe simuliranja tri scenarija. Dobiveni rezultati su pojašnjeni i grafički prikazani.

Ključne riječi: vjetroelektrane, biomasa, tržište, obnovljivi izvori, poticaji, optimizacija, MATLAB

Abstract

This thesis defines the electricity market and covers the penalties given to the market participants for causing imbalances. The review of wind power plants and biomass power plants is given, including their representation in total production of electrical energy. The thesis also covers the incentives that are being used to stimulate renewable energy sources. Lastly, the two models used for simulating three scenarios in MATLAB are described. Final results are explained and graphically shown.

Keywords: wind power plants, biomass, market, renewable sources, incentives, optimization, MATLAB

Prilog

Prilog 6.1. Tablica prvobitno očekivane proizvodnje VE

h	1	2	3	4	5	6	7	8	9	10	11	12
VE1 [MWh]	3,5	4,1	4,5	5	5,2	5,1	4,7	4,1	3,5	2,8	2,1	1,85
VE2 [MWh]	14,6	13,5	13,05	12,46	11,97	11,58	11,12	11,95	12,41	12,9	14,8	15,71
Total [MWh]	18,1	17,6	17,55	17,46	17,17	16,68	15,82	16,05	15,91	15,7	16,9	17,56
H	13	14	15	16	17	18	19	20	21	22	23	24
VE1 [MWh]	1,75	2,35	2,9	3,5	4,5	5,3	5,6	5,95	5,95	5,95	5,95	5,95
VE2 [MWh]	16,9	17,2	17,5	17,5	17,5	17,5	17,5	17,5	17,5	17	16,5	15,84
Total [MWh]	18,7	19,6	20,4	21	22	22,8	23,1	23,45	23,45	22,9	22,5	21,79

Prilog 6.2. Tablica druge očekivane proizvodnje VE

h	1	2	3	4	5	6	7	8	9	10	11	12
VE1 [MWh]	3	3	3,1	2,85	2,5	2,32	3,1	3,5	3,5	4,65	4,87	5,05
VE2 [MWh]	12,8	11,5	11,78	12,2	12,39	11,82	10,97	10,44	10,74	11,3	12,9	14,74
Total [MWh]	15,8	14,5	14,88	15,05	14,89	14,14	14,07	13,94	14,24	15,9	17,8	19,79
h	13	14	15	16	17	18	19	20	21	22	23	24
VE1 [MWh]	5,57	5,95	5,95	5,95	5,95	5,95	5,95	5,95	5,95	5,95	5,95	5,95
VE2 [MWh]	16,5	17,5	17,5	17,5	17,5	17,5	17,5	17,5	17,5	17,5	17,5	17,5
Total [MWh]	22,1	23,5	23,45	23,45	23,45	23,45	23,45	23,45	23,45	23,5	23,5	23,45

Prilog 6.3. Angažiranost elektrana na biomasu - prvi slučaj, prva očekivana proizvodnja VE

h	1	2	3	4	5	6	7	8	9	10	11	12
BM1 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM2 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM3 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
h	13	14	15	16	17	18	19	20	21	22	23	24
BM1 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM2 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM3 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Prilog 6.4. Angažiranost elektrana na biomasu - prvi slučaj, druga očekivana proizvodnja VE

h	1	2	3	4	5	6	7	8	9	10	11	12
BM1 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM2 [MWh]	2,35	3,10	2,67	2,41	2,28	2,54	1,75	2,11	1,70	0,00	0,00	0,00
BM3 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
h	13	14	15	16	17	18	19	20	21	22	23	24
BM1 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM2 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
BM3 [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Prilog 6.5. Rezultati za prvi slučaja (kupljena i prodana el. energije)

h	1	2	3	4	5	6	7	8	9	10	11	12
Das [MWh]	11,10	10,60	10,55	10,46	10,17	9,68	8,82	9,05	8,91	8,70	9,90	10,56
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	11,10	10,60	10,55	10,46	10,17	9,68	8,82	9,05	8,91	8,70	9,90	10,56
h	13	14	15	16	17	18	19	20	21	22	23	24
Das [MWh]	11,65	12,55	13,40	14,00	15,00	15,80	16,10	16,45	16,45	15,93	15,47	14,79
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	11,65	12,55	13,40	14,00	15,00	15,80	16,10	16,45	16,45	15,93	15,47	14,79

Prilog 6.6. Rezultati drugog modela (1. slučaj) – količina viška/manjka el. energije

h	1	2	3	4	5	6	7	8	9	10	11	12
Edod [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Evisak [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,03	0,20	0,87	2,23
h	13	14	15	16	17	18	19	20	21	22	23	24
Edod [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Evisak [MWh]	3,42	3,90	3,05	2,45	1,45	0,65	0,35	0,00	0,00	0,52	0,98	1,66

Prilog 6.7. Angažiranost elektrana na biomasu – 2. i 3. slučaj, prva očekivana proizvodnja VE

h	1	2	3	4	5	6	7	8	9	10	11	12
BM1 [MWh]	0,65	0,65	0,65	0,65	0,65	0,65	0,65	3,30	3,30	3,30	3,30	3,30
BM2 [MWh]	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60
BM3 [MWh]	0,90	0,90	0,90	0,90	0,90	0,90	0,90	4,60	4,60	4,60	4,60	4,60
h	13	14	15	16	17	18	19	20	21	22	23	24
BM1 [MWh]	3,30	0,65	0,65	0,65	0,65	3,30	3,30	3,30	3,30	3,30	3,30	3,30
BM2 [MWh]	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60
BM3 [MWh]	4,60	0,90	0,90	0,90	0,90	4,60	4,60	4,60	4,60	4,60	4,60	4,60

Prilog 6.8. Angažiranost elektrana na biomasu – 2. i 3. slučaj, druga očekivana proizv. VE

h	1	2	3	4	5	6	7	8	9	10	11	12
BM1 [MWh]	1,76	2,09	1,92	1,82	1,76	1,85	1,49	3,30	3,30	3,26	2,90	2,42
BM2 [MWh]	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60	8,60
BM3 [MWh]	2,14	2,56	2,30	2,14	2,07	2,24	1,81	4,60	4,60	4,44	4,13	3,25
h	13	14	15	16	17	18	19	20	21	22	23	24
BM1 [MWh]	2,04	0,65	0,65	0,65	0,65	2,99	3,13	3,30	3,30	3,05	2,91	2,60
BM2 [MWh]	8,60	4,70	5,55	6,15	7,15	8,60	8,60	8,60	8,60	8,60	8,60	8,60
BM3 [MWh]	2,44	0,90	0,90	0,90	0,90	4,26	4,42	4,60	4,60	4,33	4,01	3,64

Prilog 6.9. Rezultati za drugi slučaj (kupljena i prodana el. energija.)

h	1	2	3	4	5	6	7	8	9	10	11	12
Das [MWh]	21,25	20,75	20,70	20,61	20,32	19,83	18,97	25,55	25,41	25,20	26,40	27,06
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	21,25	20,75	20,70	20,61	20,32	19,83	18,97	25,55	25,41	25,20	26,40	27,06
h	13	14	15	16	17	18	19	20	21	22	23	24
Das [MWh]	28,15	22,70	23,55	24,15	25,15	32,30	32,60	32,95	32,95	32,43	31,97	31,29
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	28,15	22,70	23,55	24,15	25,15	32,30	32,60	32,95	32,95	32,43	31,97	31,29

Prilog 6.10. Rezultati drugog modela (2. i 3. slučaj) – količina viška/manjka el. energije

h	1	2	3	4	5	6	7	8	9	10	11	12
Edod [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	2,11	1,67	0,00	0,00	0,00
Evisak [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
h	13	14	15	16	17	18	19	20	21	22	23	24
Edod [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Evisak [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Prilog 6.11. Rezultati za treći slučaj (kupljena i prodana el. energija)

h	1	2	3	4	5	6	7	8	9	10	11	12
Das [MWh]	8,25	7,75	7,70	7,61	7,32	6,83	5,97	12,55	12,41	12,20	13,40	14,06
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	8,25	7,75	7,70	7,61	7,32	6,83	5,97	12,55	12,41	12,20	13,40	14,06
h	13	14	15	16	17	18	19	20	21	22	23	24
Das [MWh]	15,15	9,70	10,55	11,15	12,15	19,30	19,60	19,95	19,95	19,43	18,97	18,29
Dab [MWh]	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Pda [MWh]	15,15	9,70	10,55	11,15	12,15	19,30	19,60	19,95	19,95	19,43	18,97	18,29

Prilog 6.12. Tablica prihoda, rashoda i zarade po satu te kumulativne zarade – 1. slučaj

t	1	2	3	4	5	6	7	8	9	10	11	12
Prihodi	1101,09	1053,09	1034,14	1006,26	976,85	970,76	960,00	1005,92	1044,18	1029,45	1061,20	1111,60
Rashodi	148,05	195,30	168,21	151,83	143,64	160,02	110,25	132,93	107,10	0,00	0,00	0,00
Zarada	953,04	857,79	865,93	854,43	833,21	810,74	849,75	872,99	937,08	1029,45	1061,20	1111,60
Kumulativna zarada	953,04	1810,83	2676,76	3531,20	4364,41	5175,16	6024,91	6897,90	7834,98	8864,43	9925,63	11037,23
t	13	14	15	16	17	18	19	20	21	22	23	24
Prihodi	1151,34	1196,59	1223,96	1264,32	1311,03	1365,85	1528,76	1582,41	1594,25	1561,11	1518,71	1358,80
Rashodi	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
Zarada	1151,34	1196,59	1223,95	1264,32	1311,03	1365,84	1528,76	1582,41	1594,25	1561,11	1518,71	1358,80
Kumulativna zarada	12188,57	13385,16	14609,11	15873,43	17184,45	18550,30	20079,06	21661,46	23255,71	24816,82	26335,53	27694,33

Prilog 6.13. Tablica prihoda, rashoda i zarade po satu te kumulativne zarade – 2. slučaj

t	1	2	3	4	5	6	7	8	9	10	11	12
Prihodi	2052,88	1973,77	1937,98	1885,47	1834,22	1834,77	1840	2393,73	2513,33	2486,82	2470,42	2538,26
Rashodi	822,6	876,6	845,64	826,92	817,56	836,28	779,4	1419,25	1371,95	1096,2	1047,96	950,04
Zarada	1230,27	1097,16	1092,34	1058,55	1016,66	998,492	1060,6	974,476	1141,38	1390,62	1422,46	1588,22
Kumulativna zarada	1230,27	2327,44	3419,78	4478,33	5494,99	6493,48	7554,08	8528,55	9669,93	11060,6	12483	14071,2
t	13	14	15	16	17	18	19	20	21	22	23	24
Prihodi	2558,27	2157,13	2197,05	2261,39	2333,29	2882,9	3205,05	3302,03	3325,75	3276,04	3205,05	2895,22
Rashodi	864,36	407,7	461,25	499,05	562,05	1063,8	1085,4	1110,6	1110,6	1073,16	1040,04	991,08
Zarada	1693,91	1749,43	1735,8	1762,34	1771,24	1819,1	2119,65	2191,43	2215,15	2202,88	2165,01	1904,14
Kumulativna zarada	15765,1	17514,6	19250,4	21012,7	22783,9	24603	26722,7	28914,1	31129,3	33332,1	35497,1	37401,3

Prilog 6.14. Tablica prihoda, rashoda i zarade po satu te kumulativne zarade – 3. slučaj

t	1	2	3	4	5	6	7	8	9	10	11	12
Prihodi	2093,18	2041,11	2025,6	2002,34	1971,63	1951,12	1913,84	2417,91	2471,08	2449,77	2487,45	2546,06
Rashodi	822,6	876,6	845,64	826,92	817,56	836,28	779,4	1419,25	1371,95	1096,2	1047,96	950,04
Zarada	1270,57	1164,5	1179,96	1175,42	1154,07	1114,84	1134,44	998,656	1099,13	1353,57	1439,49	1596,02
Kumulativna zarada	1270,57	2435,08	3615,04	4790,46	5944,53	7059,37	8193,81	9192,46	10291,6	11645,2	13084,6	14680,7
t	13	14	15	16	17	18	19	20	21	22	23	24
Prihodi	2594,28	2197,43	2249,05	2301,69	2373,59	2908,9	3111,32	3181,39	3195,75	3148,25	3090,26	2885,47
Rashodi	864,36	407,7	461,25	499,05	562,05	1063,8	1085,4	1110,6	1110,6	1073,16	1040,04	991,08
Zarada	1729,92	1789,73	1787,8	1802,63	1811,53	1845,1	2025,92	2070,79	2085,15	2075,09	2050,22	1894,39
Kumulativna zarada	16410,6	18200,3	19988,1	21790,8	23602,3	25447,4	27473,3	29544,1	31629,2	33704,3	35754,5	37648,9